





GreenHouseSQL - масштабируемая система аналитики на PostgreSQL, Greenplum и Clickhouse

Max Vikharev, Alytics,
PGConf Moscow 2019

WHO Am I



Alytics co-founder ;)

Data engineer


Software engineer

Release engineer

DevOpsDBA

SaaS система аналитики интернет маркетинга

(Система сквозной аналитики)



<https://pgconf.ru>



Google Analytics

Битрикс24

InSales

retailCRM

мегаплан


OWOX BI

amoCRM


+ любая CRM-система или
хранилище данных через API




Alytics



source
content




costs



<https://naconf.ru>

sessions



Google Analytics

goals



sales



Битрикс24

InSales

retail CRM


мегаплан

OWOX BI

amoCRM

+ любая CRM-система или
хранилище данных через API

Alytics



Какой трафик приносит прибыль?

Применение

Таблицы


Графики

Интерактивный BI

CSV/PDF

Выгрузки по расписанию

Автоматизация



Особенности

Множество проектов - индивидуальные операции сбора данных

Регулярные ретроспективные корректировки (NOT append-only!)

Неоднородная структура фактов

Особо большие проекты


Транспонирование фактов

Непрерывное обновление контента

Синхронизации статистики три раза в день

Глубокие пересборки

Архитектура 2017



Проблемы OLAP 2017

Просадка скорости на больших проектах и глубоких периодах

Невыносимо медленные миграции схемы

Недоступные миграции данных

Сложный фейловер

Вертикальное масштабирование

Индивидуальные агрегаты для проектов

Слабоконтролируемые синхронизации с ETL

Postgresql OLAP



Требования 2017

< 1 секунды уровень сводки за любые периоды

~ 10 секунд детальные данные включая глубокие периоды

В планах все источники трафика -> новые сервисы -> больше данных

В планах мультиканальная аналитика: сложный ETL, Windows functions.
Пример.

Без раздутия стека. Python, SQL и opensource.

Идеально: обратная совместимость с старым приложением:
SQL (CTE, JOIN, Транспонирование, Множители, Сравнение периодов)

Минимальные задержки обновления контента и новых данных

Типовая архитектура DWH решений

Datalake

Change Data Capture

ETL

Выгрузка в слой колоночного хранения



Варианты на 4Q 2017

Шардинг уровня приложения (FDW, Python logic)

Postgres XL/XC

Clickhouse

pg_shard Citus

Greenplum

Greenplum

https://gpdb.docs.pivotal.io/500/best_practices/intro.html

Шардинг

MPP загрузка данных

Партиционирование

Gp 5: Pg 8.2 -> 8.3 (json, hstore)

Таблицы Heap, Appendonly, Column

GP 6: Pg 9.4 (уже 9.0)

Compression

Opensource

ANSI SQL с оконными функциями

Высокая доступность (реплики)

Цикл пилотного проекта

Первоначальный сетап

Загрузка всех данных

Тестирование производительности

Перешардирование

Доработка структуры данных

Изменение конфигурации



Загрузка Postgresql -> Greenplum

https://gpdb.docs.pivotal.io/5160/admin_guide/external/g-external-tables.html

EXTERNAL TABLE

Script

Gpfdist


File

PXF

S3

Gpfdist

http://engineering.pivotal.io/post/the_gpfdist_protocol_for_external_tables_in_greenplum_database/



Gpfdist

dbsource: gpfdist -p 8080 -d /gpfdist/

dbsource: psql -c "COPY (SELECT FROM table) TO '/gpfdist/table.csv';"

greenplum: CREATE EXTERNAL TABLE 'gpfdist://dbsource/table.csv';

greenplum: INSERT INTO mytable SELECT FROM external

HINT: лучше явный список полей везде (SELECT *, CREATE LIKE)

Gpfdist

dbsource: Out of space

Gpfdist

dbsource: mkfifo /gpfdist/table.csv

dbsource: psql -c "COPY (...) TO '/gpfdist/table.csv';" | gzip > /gpfdist/table.csv

Факторы быстродействия

https://gpdb.docs.pivotal.io/500/best_practices/schema.html

Реляционная схема

HINT: Меньше джойнов - лучше ©, JOIN по ключу шардирования - BEST

HINT: EXPLAIN покажет дорогие REDISTRIBUTE MOTION

https://gpdb.docs.pivotal.io/500/best_practices/tuning_queries.html

Шардирование

HINT: MPP шардирование - шардирование по минимальному контенту

HINT: Перекосы в данных - зло (кейс - “)

```
select gp_segment_id, count(*) from table group by gp_segment_id;
```

Партиционирование

HINT: новые партии не наследуют параметры хранения

HINT: чем больше партий - тем больше схема (2млн таблиц - ОК)

Тип хранения

HINT: heap - часто обновляемые данные, контент

HINT: appendonly + compression - статистика

HINT: columnar - надо мерять

Индексы

HINT: Дают выхлоп, надо тестить

Изменение конфигурации

https://gpdb.docs.pivotal.io/500/best_practices/workloads.html

```
optimizer: "off"  
optimizer_parallel_union: "on"  
statement_mem  
max_statement_mem  
gp_vmem_protect_limit  
gp_resqueue_priority_cpucores_per_segment  
maintenance_work_mem  
gp_workfile_compress_algorithm: "zlib"  
shared_buffers  
log_min_duration_statement
```

Автовакум выключен

... и на pg_catalog тоже

https://gpdb.docs.pivotal.io/500/best_practices/bloat.html

Интеграция в систему. Требования

Нужно переливать исторические данные (факты) [time partition]

Нужно переливать контент (измерения) [changes]

Нужно возможность инкрементальной и полной пересинхронизации из разных БД

Интеграция в прикладные приложения с минимальными усилиями

Нужна возможность дополнительных обработок данных [ETL]

По максимуму автоматизировать operations и обновлять данные без простоя приложение

Интеграция в систему. etl-gr

Новое приложение с набором демонов, работающих в фоне

Содержит конфигурацию таблиц и баз-источников

Имеет командный интерфейс для создания таблиц и полных синхронизаций

Имеет встроенный `python` фреймворк для организации ETL пайплайнов

Интеграция в систему. psql-exporter

psql-exporter - микросервис интеграции psql && gpfdist

провижинится рядом с любой базой

предоставляет API для экспорта данных на файловую систему в папку gpfdist

```
mkfifo && COPY (custom_sql) | gzip > file ; DELETE file
```

Взаимодействие etl-gp - psql-exporter

Делпоим psql-exporter на БД источник

```
root@db-olap-03 /var/docker/gpfdist/alytics_olap_01 # cat docker-compose.yml
version: '2'

services:

  gpfdist:
    image: dr.alytics.org/greenplum-loaders:5.1.0
    command: /bin/bash -c "source greenplum_loaders_path.sh; gpfdist -p 7070 -t 600 -d /gpfdist_data/ -m 655350"
    restart: always
    network_mode: host
    volumes:
      - /var/www/gpfdist/alytics_olap_01:/gpfdist_data/
      - /etc/localtime:/etc/localtime

  psql-data-exporter:
    image: dr.alytics.org/psql-exporter:master
    restart: always
    network_mode: host
    environment:
      - EXPORT_DIR=/gpfdist_data/
      - PORT=7071
      - PG_HOST=
      - PG_PORT=54351
    volumes:
      - /var/www/gpfdist/alytics_olap_01:/gpfdist_data/
      - /etc/localtime:/etc/localtime
```

Взаимодействие etl-gr - psql-exporter

Делпоим psql-exporter на БД источник

Описываем конфигурацию БД источников в etl-gr

```
DATABASES = {
    'stat': {
        'ENGINE': 'django.db.backends.postgresql',
        'NAME': os.getenv('STAT_DB_DB'),
        'USER': os.getenv('STAT_DB_USER'),
        'PASSWORD': os.getenv('STAT_DB_PASSWORD'),
        'HOST': os.getenv('STAT_DB_HOST'),
        'PORT': os.getenv('STAT_DB_PORT'),
        'GPFDIST_HOST': os.getenv('STAT_DB_GPFDIST_HOST'),
        'GPFDIST_PORT': os.getenv('STAT_DB_GPFDIST_PORT'),
        'PSQL_EXPORTER_HOST': os.environ.get('STAT_DB_GPFDIST_EXPORTER_HOST'),
        'PSQL_EXPORTER_PORT': os.environ.get('STAT_DB_GPFDIST_EXPORTER_PORT'),
        'TEST': {
            'MIRROR': 'default'
        }
    },
    ...
}
```

Взаимодействие etl-gp - psql-exporter

Делпоим psql-exporter на БД источник

Описываем конфигурацию БД источников

Описываем конфигурацию таблиц

```
class AnalyticsStatPremium(SimpleTable):
    source_db = "stat"
    table_name = "analytics_stat_premium"
    fields = {
        "time_on_site": "integer",
        "access_id": "integer",
        "pageviews": "integer",
        "new_visits": "integer",
        "date": "date",
        "content_id": "integer",
        "bounces": "integer",
        "id": "integer",
        "visits": "integer",
    }
    parameters = "appendonly=true, compresslevel=7"
    distribution = "content_id"
    partitioning = "RANGE (date) ( START (date '2012-01-01' "
        "INCLUSIVE END (date '2018-10-01' "
        "EXCLUSIVE EVERY (INTERVAL '1 week'))"
```

Взаимодействие etl-gp - psycopg2-exporter

Делпоим psycopg2-exporter на БД источник

Описываем конфигурацию БД источников

Описываем конфигурацию таблиц

Запускаем команды полной синхронизации

```
./manage.py resync_stat --tables=analytics_sessions_stat
```

Отслеживание изменений контента.

Триггерный SQL механизм отслеживания изменений

Устанавливается командой etl-gr в базу источник

Фоновый процесс в цикле переливает данные

Отслеживание изменений time partition

Воркеры приложений после завершения обновления данных по проекту репортят в etl-gr информацию о чанках (project_id, date)

Демон etl-gr сохраняет в мета-бд информацию о чанках

Фоновый процесс в цикле переливает данные по накопившимся чанкам

ETL процессы

После обновления любой из таблиц можно запустить ETL процесс

Соглашение:

Public schema - для сырых данных (Datalake)

Service schema - для результатов ETL (подготовленные данные для работы из прикладного приложения)

Один ETL процесс обработки на таблицу

Обновление без простоя

ETLM*

*M - maintenance

Worker: stat_table updated

Chunks: (project_id1, date1), ..., (project_idN, dateN) -> POST etp-gp/chunks/

Etl-gp: Chunks -> SQL: SELECT FROM stat_table WHERE project_id1, date1 -> psql-exporter

CREATE EXTERNAL TABLE external_table ... 'gpfdist://';

DELETE + INSERT INTO public.stat_table FROM external_table

Detect partition by changes dates

```
sql = ""
SELECT DISTINCT partitiontablename, partitionrank, partitionrangestart, partitionrangeend
FROM (
    SELECT date_trunc('day', date)::TEXT AS x
    FROM generate_series
    ( '{date_from}'::TIMESTAMP
    , '{date_to}'::TIMESTAMP
    , '1 day'::INTERVAL) date
    ) d,
    pg_partitions p
WHERE p.tablename = '{table}'
    AND p.partitionsschemaname = '{schema}'
    AND d.x::date >= split_part(p.partitionrangestart, '::', 1)::date
    AND d.x::date < split_part(p.partitionrangeend, '::', 1)::date;
""
```

Обновление без простоя

ETLM*

*M - maintenance

Worker: stat_table updated

Chunks: (project_id1, date1), ..., (project_idN, dateN) -> POST etp-gp/chunks/

Etl-gp: Chunks -> SQL: SELECT FROM stat_table WHERE project_id1, date1 -> psql-exporter

```
CREATE EXTERNAL TABLE external_table ... 'gpfdist://';
```

```
DELETE + INSERT INTO public.stat_table FROM external_table
```

Detect partition by changes dates

```
VACUUM ANALYZE public.stat_table_partition_w2019p1
```

Transform (public.stat_table_partition_w2019p1) -> service.stat_table_for_exchange

```
ANALYZE service.stat_table_for_exchange
```

```
EXCHANGE PARTITION service.stat_table_for_exchange -> service.stat_table_partition_w2019p1
```


```
ANALYZE ROOTPARTITION service.stat_table
```

Application -> service.stat_table

Мониторинг и контроль

Мониторинг и контроль

Доступность Greenplum - gpstate



Фейловер

Восстанавливаем

```
gprecoverseg -a
```

Если не помогло

```
gprecoverseg -aF
```

Проверяем состояние

Ребалансировка


```
gprecoverseg -r
```

Проверяем состояние

Мониторинг и контроль

Доступность Greenplum - gpstate

Лаги переливов и процессов ETL (пайплайнов) - grafana



Мониторинг и контроль

Доступность Greenplum - gpstate

Лаги переливов и процессов ETL (пайплайнов) - grafana

Per-database health check, <https://etl-gp.prod.cluster.local/health>

Админка чанков

API готовности пайплайнов и индивидуальных чанков

Профит

Все по 10 секунд без агрегатов

Сокращение ночного ворклода с 7-9 часов до 1 - 1,5

500 глубоких TRSN с 12 часов до 30 минут

Уменьшение размера кластера в 7-10 раз

gprecoverseg - восстановление в одну команду

https://gpdb.docs.pivotal.io/500/best_practices/ha.html

Мифы о железе

2 x TOP DELL -> 14 cheap noname

Сеть 1Гбит

SSD RAID 0

Недостатки

Все по 10 секунд

Быстрый слой

плоские таблицы

подготовка слоя данных для быстрых выборок

source
content

+

sessions

+

costs

+

goals

+

cost

Проблемы для GR

Глобальный планировщик

Транспонирование фактов

Clickhouse

Встроенное шардирование

Планировщик заточен под локальные данные


Встроенные вложенные структуры Goal

Мультимастер

Merge движки таблиц для обновлений в фоне

Любые запросы $\sim 10 \cdot N$ мс

Общая архитектура



Профит

10 секунд детальные данные включая глубокие периоды

Менее 1 секунды уровень сводки и BI

Быстрый MPP ETL слой с ANSI SQL и оконными функциями

In-memory быстрый слой данных

Без переписывания приложений

Задержка контента - минуты Задержка статьи - до часа*

Спасибо

Вопросы?

Max Vikharev

mvikharev@alytics.ru

@mvikharev



Opensource для psql-exporter && etl-gp: <https://alytics.ru/pg-gp-to-opensource>

Группа greenplum [RUSSIAN COMUNITY]: <https://t.me/joinchat/DYEBbRGynrZ0dL-QaKmkbw>

Группа clickhouse [RUSSIAN COMUNITY]: @clickhouse_ru

<https://www.meetup.com/Scale-out-databases-and-engines/events/257153368/>